

## APLICAÇÃO DE UMA REDE NARX NA MODELAGEM DA VELOCIDADE DE UM SMART PIG

Renan Pires de Araújo (1); Gustavo Fernandes de Lima (2); Victor Carvalho Galvão de Freitas (2); Adrião Duarte Dória Neto (1); Andrés Ortiz Salazar (1)

1 – Universidade Federal do Rio Grande do Norte. E-mails: eng.renanpires@gmail.com, adriao@dca.ufrn.br, andres@dca.ufrn.br

2 – Instituto Federal do Rio Grande do Norte (campus Parnamirim). E-mails: gustavo.lima@ifrn.edu.br, victor.carvalho@ifrn.edu.br

**Resumo:** De grande utilização na indústria de petróleo e gás, as tubulações, com o tempo de uso, podem apresentar deformidades, sujeiras em seu interior e corrosão. A fim de identificar estes defeitos, uma técnica comum é o uso de um tipo de ferramenta chamada Pipeline Inspection Gauge (PIG). Como o PIG é movimentado por meio do diferencial de pressão produzido pelo fluido sua velocidade dentro da tubulação pode variar significativamente durante a inspeção. Este trabalho visa utilizar uma rede neural artificial para modelar a velocidade do PIG através de dados do diferencial de pressão. Para tanto, foi usado um PIG protótipo, cuja velocidade foi obtida por meio de um odômetro e de uma placa eletrônica, enquanto que o diferencial de pressão foi obtido por meio de sensores de pressão instalados na tubulação de testes. A rede neural escolhida foi a rede NARX. Os resultados comprovaram a possibilidade de modelar a velocidade do PIG por meio de uma rede neural NARX, obtendo resultados bastante próximos dos reais.

**Palavras-chave:** PIG; velocidade; redes neurais; odômetro.

### 1. Introdução

É comum na indústria de petróleo e gás, independente da etapa, isto é, desde a perfuração de poços exploratórios até a distribuição de produtos advindos do petróleo cru e do gás natural, a utilização de tubulações metálicas no transporte de fluidos. Com o tempo, devido a desgastes provocados pela passagem dos fluidos no interior dos dutos e pela presença de impurezas, como areia ou algum pequeno objeto, faz-se necessário que sejam realizados ensaios a fim de verificar a integridade das paredes interna e externa dessas tubulações e a eventual necessidade de reparos (ARAÚJO, 2017).

Uma técnica de inspeção de tubulação comumente empregada pelas empresas de petróleo é o *pigging*, definida como a passagem de uma ferramenta chamada de *Pipeline Inspection Gauge* (PIG) pelo interior do duto por meio da diferença de pressão entre as regiões a montante e a jusante da ferramenta (MIRSHAMSI & RAFFEYAN, 2012).

O problema desta técnica é que o operador geralmente não possui controle direto sobre a velocidade do PIG, acarretando a perda de dados de inspeção de devido à incapacidade de leitura dos sensores presentes no PIG causado pela alta velocidade do PIG (LIMA *et al*, 2017). Além disso, a alta velocidade também pode ser

prejudicial para a estrutura física desse instrumento, podendo, por exemplo, danificar o odômetro presente em seu corpo e, com isso, não ser mais capaz de medir sua velocidade.

Com o intuito de contornar este problema, podem-se aplicar as redes neurais artificiais incorporadas na programação de controle do PIG, pretendendo, assim, estimar indiretamente a velocidade da ferramenta. Portanto, o objetivo geral deste trabalho é verificar a aplicabilidade de uma rede neural do tipo NARX na modelagem da velocidade de um PIG partindo de dados do diferencial de pressão atuante sobre este equipamento.


## 2. Fundamentação Teórica

### 2.1. Pipeline Inspection Gauge - PIG

Podendo ser construído de diversos materiais, tamanhos e formatos, o PIG pode ser dividido em três classes, dependendo de sua função primordial: os de limpeza, destinados à remoção de detritos e sujeira interna à tubulação; os de inspeção ou instrumentados, usados na inspeção das condições do duto; e os especiais, empregados em situações específicas, tais como tamponamentos e separação de fluidos transportados numa mesma tubulação (ARAÚJO, 2017).

Exceto em casos específicos (como nos esféricos), a estrutura básica de um PIG pode ser representada como ilustrada na Figura 1.

Figura 1 – Exemplo da estrutura de um PIG.



Fonte: Lima *et al* (modificado), 2017.

Separado por dois suportes, geralmente de poliuretano, o corpo do PIG, produzido em material metálico, é responsável por acomodar a parte eletrônica (sensores, circuitos eletrônicos) e as baterias que permitem a realização da inspeção interna da tubulação por este equipamento, quando dos instrumentados. Para que o PIG se movimente é empregada a força do próprio fluido transportado através da tubulação, necessitando apenas que haja uma diferença de pressão entre a região a jusante (a frente) e a montante (atrás) dele, respectivamente com baixa e alta pressões (LIMA *et al*, 2017). O odômetro instalado na parte externa do PIG tem como função fornecer um sinal elétrico

para o microcontrolador calcular a velocidade e o espaço percorrido pelo PIG durante a inspeção da tubulação.

A fim de identificar um modelo matemático que represente o movimento do PIG no interior de uma tubulação completamente horizontal, aplicou-se a Segunda Lei de Newton ao PIG (Figura 1), obtendo as equações (1), (2) e (3):

$$M.a = F_g - F_a \quad (1)$$

$$F_g = \Delta P.A \quad (2)$$

$$F_a = B.v + F_s \quad (3)$$

onde  $M$  é a massa do PIG,  $a$  é a sua aceleração,  $F_g$  é a força de pressão que age sobre o PIG, causando seu movimento,  $\Delta P$  é a diferença de pressão atuante sobre o PIG,  $A$  é a área do PIG sobre a qual o fluido exerce pressão,  $F_a$  é a força de atrito entre o PIG e a parede interna do duto,  $B$  é o coeficiente de atrito viscoso,  $v$  é a velocidade do PIG e  $F_s$  é a força de atrito seco.

Substituindo (2) e (3) em (1) e fazendo  $a = \dot{v}$ :

$$M.\dot{v} = \Delta P.A - B.v - F_s \quad (4)$$

Isolando  $\dot{v}$  e organizando os termos do lado direito da igualdade:

$$\dot{v}(t) = -\frac{B}{M}v(t) + \frac{A}{M}\Delta P(t) - \frac{1}{M}F_s(t) \quad (5)$$

A partir da equação (5), verifica-se que a velocidade do PIG é dependente principalmente do diferencial de pressão  $\Delta P(t)$ .

Como explicitado acima, para se chegar à equação (5), foi realizada a desconsideração da força da gravidade por causa da tubulação de testes estar na horizontal. Além disso, o atrito seco é formado pelo atrito estático e atrito dinâmico, sendo que o primeiro só atua quando o PIG quebra a sua inércia e entra em movimento e o segundo tem um baixo valor quando o PIG está em movimento. Dessa forma, a variável atrito seco foi desconsiderada.

Na prática, como o valor do atrito seco e do coeficiente de atrito viscoso nem sempre são fáceis de serem obtido, aplicar uma técnica de modelagem matemática na qual essas variáveis possam estar presentes no modelo final sem que seja necessário saber seu valor de antemão é bem vinda. Neste caso, uma possibilidade é a aplicação das Redes Neurais Artificiais (ARAÚJO, 2017).

## 2.2 Redes Neurais Artificiais

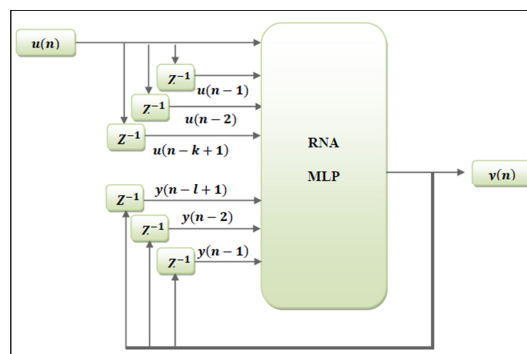
De acordo com Silva, Spatti e Flauzino (2010), as Redes Neurais Artificiais (RNA) podem ser definidas como modelos matemáticos inspirados no cérebro humano, idealizados a partir do modelo do neurônio artificial de McCulloch e Pitts,

cuja capacidade computacional é adquirida através do aprendizado por meio de exemplos.

A forma como uma RNA trabalha pode ser sintetizado da seguinte forma (OLIVEIRA, 2012): os vetores de dados de entrada são enviados, após serem ponderados de acordo com cada peso correspondente, para cada neurônio da estrutura, onde cada dado ponderado é adicionado a um limiar de ativação (valor pré-determinado), resultando num valor sobre o qual a função de ativação (função matemática pré-determinada de cada neurônio) agirá e, enfim, retornará os vetores de dados de saída da rede. Para Haykin (2001) e Pires (2012), as propriedades das RNAs referentes a aquisições de modelos matemático-computacionais, como capacidade de aprender a relação entre variáveis e a aquisição de modelos mais precisos por meio da alteração da estrutura da rede, são fatores que as destacam frente a outras técnicas de modelagem.

Há diversos modelos de RNAs, cada uma sendo mais apropriada para certa situação. Em se tratando de séries temporais, o mais indicado é o uso de redes neurais recorrentes, cujo cálculo do valor atual é baseado em valores anteriores da rede (SILVA, 2013). Uma possível rede recorrente é a NARX (*Nonlinear Auto-Regressive with eXogenous input*), ilustrada na Figura 2, que nada mais é do que uma rede multicamadas tendo como entrada a própria saída realimentada com atrasos temporais e uma entrada denominada de exógena.

Figura 2 – Exemplo de estrutura de uma rede NARX.



Fonte: Silva, 2013.

### 3. Metodologia

Para este trabalho, foi empregado um protótipo de *smart* PIG, de 6 polegadas de diâmetro e cerca de 40 cm de comprimento. Com seu corpo construído em aço galvanizado e com os suportes de isolamento feitos em poliuretano, apresenta externamente um odômetro e, no interior do seu corpo, uma placa eletrônica (composta principalmente por um microcontrolador Atmega 328 e um módulo de cartão de memória SD), responsável pela aquisição, em conjunto com o odômetro, e gravação dos dados de velocidade do PIG, e um conjunto de baterias, para o funcionamento da placa eletrônica.

Para a simulação de uma corrida com o PIG, foi utilizada a tubulação de testes presente na Universidade Federal do Rio Grande do Norte. Com aproximadamente 55 metros de comprimento e apresentando 06 pontos de coleta de dados de pressão, a tubulação possui duas válvulas de alívio de pressão, por meio das quais é realizada a diminuição da pressão a jusante do PIG, causando um diferencial de pressão aplicado ao PIG e, conseqüentemente, sua movimentação. O fluido propulsor empregado foi o ar comprimido.


Para a aquisição dos dados de pressão ao longo da tubulação, foram empregados transmissores de pressão modelo NP 300, da NOVUS, distribuídos ao longo de todo o comprimento do duto. Os valores lidos foram, então, enviados a um controlador lógico programável modelo TPW-03 60HT-A, da marca WEG, e redirecionados a um sistema supervisor, a fim de que fosse realizado um mapeamento das leituras durante o teste.

A correlação entre os dados de diferencial de pressão e velocidade foi realizada por meio de uma rede neural NARX, empregando, para isso, um *software* matemático. O algoritmo de treinamento usado foi o Levenberg-Marquardt e, devido ao relativamente pequeno número de amostras para o treinamento e validação da rede, foi aplicada a técnica de validação cruzada.

#### 4. Resultados e Discussões

A Figura 3 ilustra o perfil de velocidade do PIG durante o teste, assim como a distância percorrida pelo mesmo ao longo da tubulação.

Figura 3 – Perfil da velocidade do PIG e sua distância percorrida no trecho analisado.




Fonte: Autor.

A partir da Figura 3, pode-se verificar que o PIG atingiu velocidades máximas próximas a 20 m/s durante o teste, sendo que em maior parte do tempo, sua velocidade ficou abaixo de 10 m/s. Além do mais, percebe-se também que o movimento do PIG protótipo não é constante, alternando momentos de parada, velocidade baixa e velocidade alta.

A Figura 4 ilustra os diferenciais de pressão obtidas ao longo do trecho percorrido pelo PIG. Cada variável  $DifP$  representa uma região da tubulação entre dois sensores consecutivos.

Figura 4 – Diferença de pressão nas regiões entre sensores no trecho analisado.




Fonte: Autor.

A partir da Figura 4, pode-se verificar a passagem do PIG ao longo da tubulação, pois, segundo Freitas (2016), quando o PIG passa por uma região entre dois sensores de pressão, há a identificação de um diferencial de pressão em torno do PIG, causador de seu movimento.

Na Figura 5 está apresentada a correlação entre as Figuras 3 e 4.

Figura 5 – Correlação entre o diferencial de pressão sobre o PIG e sua velocidade.



Fonte: Autor.

É possível identificar, por meio da Figura 5, uma evidente correlação entre o diferencial de pressão atuante sobre o PIG e sua velocidade, por meio da semelhança entre os dois gráficos. A partir dos dados da Figura 5, foi criado um conjunto de pares ordenados (diferença de pressão, velocidade) a serem utilizados no treinamento e na validação da rede NARX, a fim de modelar a velocidade do PIG por meio do diferencial de pressão atuante sobre ele.


A quantidade de dados de velocidade usada foi de 56 amostras. Este valor é menor que o total de dados adquiridos devido ao tratamento na escolha dos valores pois foi identificado, após tratamento estatístico, a presença de *outliers*, que poderiam prejudicar a eficiência da



RNA. De acordo com Haykin (2001), esta pequena quantidade de dados disponíveis para o treinamento da rede pode causar a inefetividade da etapa de treinamento. A fim de contornar este problema, foi empregada a técnica de validação cruzada, conforme o trabalho de Araújo (2017).

Após o teste de várias estruturas de redes NARX, variando a quantidade de neurônios na camada intermediária e a de unidades de atrasos na entrada e na saída da rede, obteve-se como melhor resultado a apresentada na Figura 6: uma rede NARX com 15 neurônios, 1 atraso na entrada e 2 atrasos na saída.

Figura 6 – Resultado da simulação de velocidade usando a rede NARX proposta.



Fonte: Autor.

Pode-se verificar o ótimo resultado obtido na comparação entre o resultado da simulação da rede NARX e a velocidade real apresentada pelo PIG durante o teste. Este fato comprova que a rede neural treinada conseguiu, por meio do diferencial de pressão, prever a velocidade do PIG com uma diferença de, no máximo, 0,5 m/s, em geral.

Vale destacar que, apesar de poucos pontos ultrapassarem a margem de erro, isso foi devido: ao pequeno número de pares ordenados disponíveis na etapa de treinamento, fato a ser contornado em futuros testes, e a quantidade de variações bruscas do valor de velocidade, conhecidas como eventos de tiros. Porém, estes poucos pontos não reduzem a importância do resultado alcançado, visto que o modelo foi obtido sem a necessidade de dados técnicos sobre o PIG (tal como massa) e sobre a tubulação (material de construção), dados requeridos em outras técnicas de modelagem, e a boa aproximação alcançada em relação aos valores reais.

## 5. Conclusões

Neste trabalho foram apresentados o treinamento e validação de uma rede neural NARX para a modelagem da velocidade de um *smart* PIG. O trabalho também mostrou a utilização

de um PIG protótipo para obtenção de dados de velocidade e de uma tubulação de testes que forneceu dados de diferencial de pressão. Os dados de pressão foram submetidos na rede neural e esta produziu valores de velocidade preditos com sucesso e de baixo erro quando comparados com os valores de velocidade do PIG protótipo. A principal contribuição deste trabalho é propor uma aplicação para redes neurais capaz de prever a velocidade de um *smart* PIG permitindo, assim, uma alternativa ao odômetro, caso este seja danificado.

## 7. Referências

- ARAÚJO, R. P. **Modelagem da velocidade de um PIG instrumentado usando redes neurais artificiais**. Dissertação (Mestrado em Ciências e Engenharia de Petróleo), PPGCEP, UFRN, Natal – RN, 2017. 67fls.
- FREITAS, V. C. G. **Desenvolvimento de um sistema para supervisão de PIGs em um duto de testes**. Dissertação (Mestrado em Ciências e Engenharia de Petróleo), PPGCEP, UFRN, Natal, 2016. 62 fls.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed., Bookman, Porto Alegre, 2001. Tradução de Paulo Martins Engel.
- LIMA, G. F.; FREITAS, V. C. G.; ARAÚJO, R. P.; MAITELLI, A. L.; SALAZAR, A. O. *PIG's speed estimated with pressure transducers Hall effect sensor: an industrial application of sensors to validate a testing laboratory*. **Sensors**, v. 17, 2017.
- MIRSHAMSI, M.; RAFEEYAN, M. *Speed control of pipeline PIG using the QFT method*. **Oil and Gas Science and Technology**, v. 67, n. 4, p. 693-701, 2012.
- OLIVEIRA, A. A. **Seleção de poços para operações de estimulação utilizando inteligência artificial**. Projeto (Graduação em Engenharia de Petróleo), Escola Politécnica, Centro de Tecnologia, UFRJ, Rio de Janeiro – RJ, 2012. 88 fls.
- PIRES, P. R. M. **Processamento inteligente de sinais de pressão e temperatura adquiridos através de sensores permanentes em poços de petróleo**. Dissertação (Mestrado em Ciências com área de concentração em Automação na Indústria de Petróleo e Gás Natural), PPGCEP, UFRN, Natal, 2012. 73 fls.
- SILVA, F. F. N. **Um modelo híbrido para previsão de curvas de produção de petróleo**. Dissertação (Mestrado em Ciências e Engenharia de Petróleo), PPGCEP, UFRN, Natal, 2013. 91 fls.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas – Curso prático**. 1. ed., Artliber, São Paulo, 2010.